



APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO E CLASSIFICAÇÃO DE FRATURAS EM RADIOGRAFIAS MUSCULOESQUELÉTICAS: REVISÃO DA LITERATURA

APLICAÇÕES DA INTELIGÊNCIA ARTIFICIAL NA DETECÇÃO E CLASSIFICAÇÃO DE FRATURAS EM RADIOGRAFIAS MUSCULOESQUELÉTICAS: REVISÃO DA LITERATURA

APLICACIONES DE LA INTELIGENCIA ARTIFICIAL EN LA DETECCIÓN Y CLASIFICACIÓN DE FRACTURAS EN RADIOGRAFÍAS MUSCULOESQUELÉTICAS: REVISIÓN DE LA LITERATURA

Bruno Dal Pozzo¹, Rafael Barrueco Tavares², Patricia Domingos Noro da Silva³, Bianca Davibida Brustulim⁴, Ana Júlia Amaral de Carvalho⁵

DOI: 10.54899/dcs.v23i88.4885

Recibido: 09/03/2026 | Aceptado: 11/03/2026 | Publicación en línea: 13/03/2026.

RESUMO

Mapear e discutir as aplicações de inteligência artificial (IA) na detecção, classificação e localização de fraturas em radiografias musculoesqueléticas. O estudo baseia-se em uma revisão da literatura conduzida com buscas ativas nas bases PubMed/MEDLINE, Scopus, Cochrane Library, LILACS e SciELO, englobando o período de 2016 a junho de 2025, analisando artigos originais e de revisão sobre redes neurais aplicadas ao trauma ortopédico. As evidências apontam que arquiteturas profundas, como ResNet, DenseNet e detectores como YOLO, atingem altos níveis de acurácia, sensibilidade e especificidade (frequentemente entre 80% e 95%) para detecção de fraturas. Observou-se que a IA atua extraindo características complexas das imagens, reduzindo o tempo de emissão de laudos e minimizando a variabilidade interobservador em ambientes de emergência, prestando auxílio vital em fraturas de difícil visualização. Entretanto, persistem limitações metodológicas na literatura atual, como viés de espectro, bases de dados de centro único e escassez de avaliações multicêntricas com validação externa. Conclui-se que a IA apresenta elevado potencial como ferramenta de suporte à decisão clínica e triagem radiológica de fraturas. A transição para a prática ortopédica, no entanto, requer maior transparência algorítmica e explicabilidade para garantir a segurança do paciente.

¹ Graduando em Medicina, Centro Universitário Cesumar (UNICESUMAR), Maringá, Paraná, Brasil.
E-mail: brunodalpozzo_2012@hotmail.com Orcid: <https://orcid.org/0009-0008-9687-1447>

² Graduando em Medicina, Centro Universitário Cesumar (UNICESUMAR), Maringá, Paraná, Brasil.
E-mail: rafaelbaru@icloud.com Orcid: <https://orcid.org/0009-0002-9174-1156>

³ Mestre em Promoção da Saúde, Centro Universitário Cesumar (UNICESUMAR), Maringá, Paraná, Brasil.
E-mail: patynoro@gmail.com

⁴ Graduanda em Medicina, Centro Universitário Cesumar (UNICESUMAR), Maringá, Paraná, Brasil.
E-mail: biancabrustulim@gmail.com

⁵ Graduanda em Medicina, Centro Universitário Cesumar (UNICESUMAR), Maringá, Paraná, Brasil.
E-mail: carvalho.anaamaral@gmail.com Orcid: <https://orcid.org/0009-0001-2638-1652>

Palavras-chave: Inteligência Artificial. Radiografia. Fraturas Ósseas. Ortopedia.

ABSTRACT

To map and discuss the applications of artificial intelligence (AI) in the detection, classification, and localization of fractures in musculoskeletal radiographs. The study is based on a literature review conducted through active searches in PubMed/MEDLINE, Scopus, Cochrane Library, LILACS, and SciELO databases (2016-2025), analyzing original and review articles on neural networks applied to orthopedic trauma. Evidence indicates that deep architectures, such as ResNet, DenseNet, and detectors like YOLO, achieve high levels of accuracy, sensitivity, and specificity (often between 80% and 95%) for fracture detection. AI was observed to operate by extracting complex image features, reducing reporting time, and minimizing interobserver variability in emergency settings, providing vital assistance in subtle fractures. However, significant methodological limitations persist in current literature, such as spectrum bias, use of single-center databases, and a scarcity of multicenter evaluations with robust external validation. It is concluded that AI presents immense potential as a clinical decision support tool and radiological triage for fractures. The transition to daily orthopedic practice, however, requires greater algorithmic transparency and explainability to ensure patient safety.

Keywords: Artificial Intelligence. Radiography. Bone Fractures. Orthopedics

RESUMEN

Mapear y discutir las aplicaciones de la inteligencia artificial (IA) en la detección, clasificación y localización de fracturas en radiografías musculoesqueléticas. El estudio se basa en una revisión de la literatura realizada con búsquedas activas en las bases de datos PubMed/MEDLINE, Scopus, Cochrane Library, LILACS y SciELO (2016-2025), analizando artículos originales y de revisión sobre redes neuronales aplicadas al trauma ortopédico. La evidencia señala que arquitecturas profundas, como ResNet, DenseNet y detectores como YOLO, alcanzan altos niveles de precisión, sensibilidad y especificidad (frecuentemente entre 80% y 95%) para la detección de fracturas. Se observó que la IA actúa extrayendo características complejas de las imágenes, reduciendo el tiempo de emisión de informes y minimizando la variabilidad interobservador en entornos de emergencia, brindando asistencia vital en fracturas sutiles. Sin embargo, persisten limitaciones metodológicas significativas, como el sesgo de espectro, el uso de bases de datos de centros únicos y la escasez de evaluaciones multicéntricas con validación externa. Se concluye que la IA presenta un inmenso potencial como herramienta de apoyo a la decisión clínica y triaje radiológico de fracturas. Sin embargo, su transición a la práctica ortopédica requiere mayor transparencia algorítmica y explicabilidad para garantizar la seguridad del paciente.

Palabras clave: Inteligencia Artificial. Radiografía. Fracturas Óseas. Ortopedia.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

Fraturas musculoesqueléticas representam um importante problema de saúde pública, com alta incidência em pronto-atendimento e serviços de ortopedia. Radiografias simples são o primeiro exame solicitado para avaliar fraturas de punho, mão, tornozelo, joelho, quadril/pelve, coluna e costelas. Apesar de amplamente disponíveis, a interpretação de radiografias é influenciada pela experiência do observador, variando entre profissionais e contextos clínicos. Em situações de alto volume, como emergências, a sobrecarga de trabalho pode atrasar laudos e dificultar o reconhecimento de fraturas sutis, impactando o prognóstico do paciente (Mellon et al., 2025; Anderson et al., 2023).

Diante desse panorama, o presente trabalho tem como objetivo realizar uma revisão da literatura das aplicações de inteligência artificial na detecção, classificação e localização de fraturas em radiografias musculoesqueléticas.

REFERENCIAL TEÓRICO

A Inteligência Artificial (IA) é um termo abrangente que descreve sistemas computacionais capazes de produzir saídas, como previsões, recomendações ou decisões, a partir de objetivos definidos por humanos (NIST, 2024a). Dentro desse campo, o aprendizado de máquina (Machine Learning) refere-se a métodos em que o desempenho do algoritmo melhora com a exposição aos dados, sem a necessidade de programação explícita de regras. Uma subcategoria avançada desse campo é o aprendizado profundo (Deep Learning), que se baseia em múltiplas camadas de processamento para aprender representações hierárquicas e abstratas, impulsionando ganhos marcantes no reconhecimento visual de imagens médicas (Chartrand et al., 2017; Hosny et al., 2018). No contexto da radiologia ortopédica, é crucial destacar que a IA empregada é predominantemente discriminativa e preditiva, focada em classificar e detectar fraturas reais, diferindo drasticamente da IA generativa, cuja finalidade é criar conteúdo sintético inédito a partir da emulação de dados (Tejani et al., 2024; NIST, 2024b).

O diagnóstico radiográfico de fraturas musculoesqueléticas assenta na identificação de descontinuidades na linha cortical óssea, desvios anatômicos e alterações sutis no padrão trabecular da medular. Nos últimos anos, os avanços no aprendizado profundo (deep learning), especialmente através das Redes Neurais Convolucionais (CNNs) e arquiteturas derivadas

(ResNet, DenseNet, EfficientNet, YOLO e transformers), revolucionaram a extração destes achados imaginológicos (Kuo et al., 2022).

Em termos algorítmicos, as CNNs otimizam a percepção visual por meio de extração hierárquica de características: as camadas convolucionais iniciais atuam como filtros de baixo nível, detectando gradientes agudos de contraste e quebras de bordas, elementos que correspondem diretamente às fraturas corticais. À medida que a informação avança para camadas mais profundas, a rede reconhece padrões espaciais complexos e não lineares, como a impactação trabecular ou o edema de tecidos moles adjacentes ao trauma (Lindsey et al., 2018).

Este mecanismo de processamento matemático torna-se particularmente valioso na detecção de fraturas ocultas ou localizadas em zonas de alta densidade e sobreposição óssea. Em regiões anatômicas complexas, como o escafoide ou o colo do fêmur, a sobreposição das estruturas articulares frequentemente mascara o traço de fratura para o olho humano, levando a falsos negativos que podem evoluir para necrose avascular ou pseudoartrose. A capacidade de inteligência artificial manter uma análise constante em zonas cinzentas de percepção visual justifica a sua aplicação crescente nestes cenários clínicos, oferecendo um desempenho preditivo comparável ao de médicos especialistas experientes (Thian et al., 2019; Sato et al., 2021).

Atualmente, a literatura sobre IA aplicada ao trauma ortopédico estende-se a múltiplas tarefas. No esqueleto apendicular, modelos de detecção e classificação de fraturas distais do rádio utilizam CNNs e detectores de objetos para estratificação de risco (Anttila et al., 2023; Kim et al., 2021; Yang et al., 2024), enquanto no tornozelo e pé, algoritmos de classificação multi-rótulo diferenciam lesões maleolares e do calcâneo (Olczak et al., 2024). No esqueleto axial e na pelve, algoritmos segmentam fraturas trocântéricas, acetabulares e vertebrais, com integração progressiva a sistemas de classificação internacional como a AO/OTA (Lee et al., 2024; Murata et al., 2020; Yilmaz et al., 2025). Modelos de detecção rápida, como o YOLO, são também empregados para a triagem prioritária de fraturas de costelas em ambientes de emergência (Bai et al., 2023).

Apesar dos progressos algorítmicos, a translação destes modelos para a prática ortopédica enfrenta desafios metodológicos. A literatura indica que o treinamento em conjuntos de dados restritos, muitas vezes provenientes de um único centro gera um fenômeno de overfitting. A diversidade de protocolos de aquisição de imagem e as variações na densidade óssea da população comprometem a generalização dos algoritmos. Além disso, persistem debates substanciais sobre a falta de validação externa multicêntrica e as implicações éticas da utilização de modelos em

"caixa-preta", exigindo mecanismos de explicabilidade (como os mapas de calor) para garantir a segurança clínica e a auditabilidade do diagnóstico (Brady; Neri, 2020; Tejani et al., 2024).

METODOLOGIA

Trata-se de uma revisão da literatura, de caráter descritivo e discursivo, com o objetivo de mapear e debater o estado da arte das aplicações de inteligência artificial (IA) na detecção, classificação e localização de fraturas em radiografias musculoesqueléticas. A busca por evidências científicas foi realizada nas bases de dados PubMed/MEDLINE, Scopus, Cochrane Library, LILACS e SciELO, englobando publicações no período de 2016 a junho de 2025.

A estratégia de busca utilizou combinações de descritores (DeCS/MeSH) e palavras-chave, incluindo o núcleo principal: ("fracture" OR "musculoskeletal") AND ("radiograph" OR "X-ray") AND ("deep learning" OR "artificial intelligence" OR "convolutional" OR "transformer"). Adicionalmente, as listas de referências dos artigos selecionados foram examinadas de forma ativa para a identificação de trabalhos complementares pertinentes ao tema (técnica de snowballing).

Para a construção do referencial teórico, foram selecionados artigos originais e de revisão, publicados nos idiomas português, inglês e espanhol, que abordassem o emprego de redes neurais convolucionais (CNNs) e arquiteturas derivadas no contexto do trauma ortopédico. A análise do material priorizou a extração de dados qualitativos e conceituais, com foco na compreensão dos mecanismos algorítmicos, nas métricas de desempenho (sensibilidade, especificidade e acurácia), nas limitações metodológicas (como viés de espectro e ausência de validação externa) e na aplicabilidade clínica imediata dessas tecnologias.

RESULTADOS E DISCUSSÃO

A busca na literatura evidenciou uma tendência crescente de publicações sobre o tema a partir de 2018, com pico em 2023–2024. Embora a pesquisa metodológica tenha englobado o período a partir de 2016, não foram encontrados achados relevantes ou publicações que preenchessem os critérios de inclusão nos anos de 2016 e 2017, refletindo a incipiência das arquiteturas de deep learning aplicadas à ortopedia radiológica nesse período inicial. A maioria dos trabalhos é de origem asiática (China, Coreia do Sul, Japão, Turquia) e norte-americana. As

arquiteturas mais empregadas foram CNNs profundas como ResNet, DenseNet, EfficientNet e VGG, bem como detectores baseados em YOLO e Mask R-CNN. As métricas mais reportadas foram acurácia, sensibilidade, especificidade, AUROC e F1-score. A maioria realizou validação interna; cerca de um terço empregou validação externa em instituições distintas, e uma minoria comparou a performance diretamente com especialistas.

Em relação à detecção e triagem de fratura, o objetivo principal da maioria dos estudos foi detectar a presença ou ausência de fratura em radiografias isoladas. Modelos baseados em ResNet e EfficientNet alcançaram alta sensibilidade e especificidade. Anderson et al. (2023) demonstraram que o suporte de IA reduziu a diferença de acurácia entre residentes e radiologistas experientes. Kim et al. (2021) aplicaram CNNs para detectar fraturas rádio-ulnares em emergência, relatando AUROC de 0,97 e redução do tempo de leitura dos clínicos. Murata et al. (2020) desenvolveram modelo para detecção de fraturas vertebrais na coluna, com sensibilidade de 88% e especificidade de 89%.

Na classificação e tipologia, diversos trabalhos classificaram fraturas em categorias específicas. Anttila et al. (2023) utilizaram modelo de segmentação para classificar fraturas distais do rádio, obtendo acurácia de 87%. Lee et al. (2024) apresentaram método de classificação AO/OTA de fraturas pélvicas usando deep learning, com acurácia geral de 84%.

Para localização e segmentação, a identificação precisa da região fraturada é crucial para guiar o tratamento. Bai et al. (2023) construíram modelo YOLOv3 para detectar fraturas de costelas com alta precisão (mAP de 0,88). A explicabilidade foi explorada por meio de mapas de calor que evidenciam a região fraturada, contribuindo para a confiança clínica.

Analisando por região anatômica, estudos focados no punho avaliam fraturas do rádio distal, ulna distal e escafoide. Yang et al. (2024) treinaram CNN para detectar e classificar fraturas do escafoide, relatando sensibilidade de 90% e melhoria na precisão dos residentes. No tornozelo e pé, Olczak et al. (2024) validaram externamente modelo multi-rótulo para classificação de fraturas de tornozelo, obtendo sensibilidade de 85% e especificidade de 88% em conjunto independente. Fraturas de quadril/pelve são de alto impacto clínico. Sato et al. (2021) demonstraram que IA melhorou a acurácia de residentes na detecção de fraturas de quadril, elevando a sensibilidade de 81% para 94%. Yilmaz et al. (2025) compararam modelo automático com 35 clínicos, mostrando acurácia superior ao da maioria dos especialistas. Outras regiões também são abordadas na literatura: Magnéli et al. (2023) e Chung et al. (2018) classificaram fraturas do ombro e úmero proximal em radiografias, alcançando excelentes taxas de acurácia.

González et al. (2025) combinaram classificação e segmentação para fraturas de quadril, utilizando mapas de calor interpretáveis.

Apesar dos altos índices de acurácia reportados, a translação desses algoritmos para a prática clínica diária esbarra na barreira da explicabilidade. Na ortopedia e traumatologia, um laudo binário ('presença' ou 'ausência' de fratura) é insuficiente para a tomada de decisão; a equipe médica necessita visualizar a exata morfologia e localização do traço de fratura para definir a conduta conservadora ou o planejamento pré-operatório da osteossíntese. Nesse cenário, o uso de mapas de calor (Saliency Maps) e segmentação anatômica tem se mostrado um diferencial crítico. Estudos como os de Bai et al. (2023) e González et al. (2025) demonstram que ao evidenciar visualmente a região anatômica que justificou a predição da rede neural, quebra-se o paradigma da 'caixa-preta' algorítmica. Essa transparência não apenas aumenta a confiança do cirurgião na ferramenta, mas também a transforma em um instrumento pedagógico valioso para médicos residentes e plantonistas em emergências de alto volume.

Contudo, a validação clínica dessas ferramentas ainda enfrenta um obstáculo metodológico severo: o viés de espectro e a carência de validação externa. Grande parte dos modelos atuais é treinada utilizando bancos de dados de centros únicos, frequentemente compostos por uma proporção irreal de fraturas evidentes e traumas de alta energia. O mecanismo desse viés gera um fenômeno de overfitting (sobreajuste), no qual o algoritmo atinge especificidades quase perfeitas em seu ambiente de treinamento, mas apresenta quedas significativas de desempenho ao ser testado em populações externas ou na detecção de fraturas ocultas e sem desvio (como fraturas capilares de escafoide ou colo do fêmur incipiente). Estudos recentes de revisão (Elbahi et al., 2025; Mellon et al., 2025) reforçam que, para garantir a segurança do paciente na triagem de emergência, a adoção dessas tecnologias dependerá obrigatoriamente da testagem multicêntrica, garantindo que a IA seja capaz de generalizar seus achados frente às mais variadas densidades ósseas, idades e qualidades técnicas de aquisição radiográfica.

CONCLUSÃO

Esta revisão da literatura constatou que as aplicações de inteligência artificial para detecção, classificação e localização de fraturas em radiografias musculoesqueléticas têm avançado rapidamente nos últimos anos. Modelos baseados em redes neurais alcançam alto

desempenho, com sensibilidade e acurácia frequentemente acima de 80–90%, demonstrando que a IA pode reduzir a variabilidade interobservador e aumentar a eficiência dos fluxos de trabalho. No entanto, persistem desafios significativos: pequena escala de amostras, falta de validação externa multicêntrica e ausência de avaliação de explicabilidade. Em síntese, a IA tem potencial para transformar o diagnóstico radiográfico, mas sua adoção exigirá rigor científico e colaboração multidisciplinar.

DECLARAÇÃO DE USO DE INTELIGÊNCIA ARTIFICIAL

Os autores declaram que ferramentas de inteligência artificial baseadas em grandes modelos de linguagem (*Large Language Models*) foram utilizadas neste trabalho com o propósito de auxiliar na revisão gramatical, aprimoramento da fluidez do texto, adequação estrutural às normas de formatação ABNT e como ferramenta de suporte na busca, rastreamento e identificação inicial de literatura científica relevante. Todo o planejamento metodológico, a leitura crítica, a seleção definitiva dos artigos incluídos, a discussão e a elaboração das conclusões são de autoria exclusiva e de responsabilidade integral dos autores humanos.

REFERÊNCIAS

ANDERSON, P. G. et al. **Deep learning assistance closes the accuracy gap in fracture detection across clinician types.** *Clinical Orthopaedics and Related Research*, v. 481, n. 3, p. 580-588, 2023.

ANTTILA, T. T. et al. **Detecting distal radius fractures using a segmentation-based deep learning model.** *Journal of Digital Imaging*, v. 36, n. 2, p. 679-687, 2023.

BAI, J. et al. **Construction and application of rib fracture diagnosis model based on YOLOv3 algorithm.** *Fa Yi Xue Za Zhi*, v. 39, n. 4, p. 343-349, 2023.

BRADY, A. P.; NERI, E. **Artificial intelligence in radiology—ethical considerations.** *Diagnostics*, v. 10, n. 4, p. 231, 2020.

CHARTRAND, G. et al. **Deep learning: a primer for radiologists.** *RadioGraphics*, v. 37, n. 7, p. 2113-2131, 2017.

CHUNG, S. W. et al. **Automated detection and classification of the proximal humerus fracture by using deep learning algorithm.** *Acta Orthopaedica*, v. 89, n. 4, p. 468-473, 2018.

ELBAHI, M. K. et al. **Artificial intelligence in fracture diagnosis on radiographs: evidence, pitfalls, and pathways for clinical integration (2020-2025)**. Cureus, v. 17, n. 1, p. e12551796, 2025.

GONZÁLEZ, G. et al. **Classification and segmentation of hip fractures in X-rays: highlighting fracture regions for interpretable diagnosis**. Insights into Imaging, v. 16, p. 86, 2025.

HOSNY, A. et al. **Artificial intelligence in radiology**. Nature Reviews Cancer, v. 18, n. 8, p. 500-510, 2018.

KIM, M. W. et al. **Application of convolutional neural networks for distal radio-ulnar fracture detection on plain radiographs in the emergency room**. Clinical and Experimental Emergency Medicine, v. 8, n. 2, p. 120-127, 2021.

KUO, R. X. et al. **Artificial intelligence in fracture detection: a systematic review and meta-analysis**. Radiology, v. 304, n. 1, p. 50-62, 2022.

LEE, S. H. et al. **Automated AO/OTA classification of pelvic fractures on pelvic radiographs using deep learning**. Scientific Reports, v. 14, p. 20548, 2024.

LINDSEY, R. V. et al. **Deep neural network improves fracture detection by clinicians**. Proceedings of the National Academy of Sciences, v. 115, n. 45, p. 11591-11596, 2018.

MAGNÉLI, M. et al. **Deep learning classification of shoulder fractures on plain radiographs of the humerus, scapula and clavicle**. PLOS ONE, v. 18, n. 8, p. e0289808, 2023.

MELLON, M. et al. **Artificial intelligence interpretation of upper extremity trauma radiographs: a systematic review and meta-analysis**. JSES Reviews, Reports and Techniques, v. 5, n. 3, p. 435-443, 2025.

MURATA, K. et al. **Artificial intelligence for the detection of vertebral fractures on plain spinal radiography**. Scientific Reports, v. 10, p. 20031, 2020.

NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY (NIST). **Artificial Intelligence Risk Management Framework (AI RMF)**. Gaithersburg: U.S. Department of Commerce, 2024a. Disponível em: <https://www.nist.gov/artificial-intelligence>. Acesso em: 25 fev. 2026.

NATIONAL INSTITUTE OF STANDARDS AND TECHNOLOGY (NIST). **Glossary of Artificial Intelligence Terms**. Gaithersburg: U.S. Department of Commerce, 2024b. Disponível em: <https://www.nist.gov>. Acesso em: 25 fev. 2026.

OLCZAK, J. et al. **External validation of an artificial intelligence multi-label deep learning model capable of ankle fracture classification**. BMC Musculoskeletal Disorders, v. 25, p. 788, 2024.

SATO, Y. et al. **Artificial intelligence improves the accuracy of residents in the diagnosis of hip fractures: a multicenter study.** BMC Musculoskeletal Disorders, v. 22, p. 407, 2021.

TEJANI, A. S. et al. **Integrating and adopting AI in the radiology workflow: a primer for standards and IHE profiles.** Radiology, v. 311, n. 3, p. e232653, 2024.

THIAN, Y. L. et al. **Convolutional neural networks for automated fracture detection and localization on wrist radiographs.** Radiology: Artificial Intelligence, v. 1, n. 1, p. e180001, 2019.

YANG, T. H. et al. **Detection and classification of scaphoid fractures in radiograph by using a convolutional neural network.** Diagnostics, v. 14, n. 21, p. 2425, 2024.

YILMAZ, A. et al. **An automated hip fracture detection and classification system on pelvic radiographs and comparison with 35 clinicians.** Scientific Reports, v. 15, p. 16001, 2025.